



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

ZAOSTŘENÍ RENTGENOVÝCH SNÍMKŮ S GEOMETRICKÝM ROZMAZÁNÍM

RESTORATION OF X-RAY IMAGES WITH GEOMETRIC BLUR

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

JURAJ SOKOL

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. MICHAL HRADIŠ, Ph.D.

BRNO 2018

Abstrakt

Cielom tejto práce je porovnať rôzne metódy zaostrovania rentgenových snímkov. V riešení sú použité metódy, ktoré na zostrovanie používajú konvolučné jadro. Výsledky sú experimentálne porovnané a vyhodnotené kvantitatívnymi metódami.

Abstract

This thesis aims to compare various image restoration methods on x-ray images. These methods use point spread function to remove blur introduced in images. These methods are experimentally compared.

Klíčové slova

zaostrovanie snímkov, rtg, psf, konvolučné jadro, šum

Keywords

image sharpening, x-ray, psf, point spread function, noise

Citácia

SOKOL, Juraj. *Zaostření rentgenových snímků s geometrickým rozmazáním*. Brno, 2018. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Michal Hradiš, Ph.D.

Zaostření rentgenových snímků s geometrickým rozmazáním

Prehlásenie

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne pod vedením pána Ing. Michala Hradiša, Ph.D. Ďalšie informácie a technické zázemie mi poskytla Lucie Svobodů. Uviedol som všetky literárne publikácie a zdroje, z ktorých som čerpal.

.....

Juraj Sokol
16. mája 2018

Podakovanie

Ďakujem vedúcemu tejto bakalárskej práce Ing. Michalovi Hradišovi, Ph.D. za cenné rady, ochotu a čas, ktorý mi venoval. Ďakujem patrí aj Lucii Svobodů.

Obsah

1	Úvod	2
2	Rentgen	4
2.1	Zdroj rentgenového žiarenia	4
2.2	Detektor rentgenového žiarenia	6
2.3	Rozlíšenie rentgenu	6
2.4	Geometrická neostrosť	6
3	Zaostrenie snímkov	8
3.1	Matematický popis rozostrenia snímku	8
4	Konvolučné jadro (PSF)	10
4.1	Výpočet konvolučného jadra z geometrie prístroja	11
4.2	Odhad konvolučného jadra z kalibračného vzorku	11
4.3	Vytvorenie konvolučného jadra	13
5	Automatická kalibrácia zaostrovania v rentgenových prístrojoch	14
6	Zaostrovacie metódy	15
6.1	Inverzný filter	15
6.2	Lucy-Richardson deconvolution	16
6.3	Wienerov filter	16
6.4	Stochastická deconvolúcia	16
7	Experimenty	17
7.1	Úprava snímkov pomocou konvolúcie	18
7.2	Experimenty s konvolučným jadrom	20
7.3	Experimenty s dekonvolučnými metódami	22
8	Záver	29
	Literatúra	30

Kapitola 1

Úvod

Rentgeny majú široké využitie. Najčastejšie sa používajú v lekárstve ale čoraz viac sa objavujú pri kontrole výrobkov, tzv priemyselná defektoskopia alebo pri bezpečnostnej kontrole. Pri takýchto kontrolách je nutné mnohokrát dosiahnuť čo najväčšieho rozlíšenia a tým pádom aj ostrého snímku. Toto je v niektorých prípadoch obtiažne alebo neefektívne.

Ostrosť snímku je závislá na geometrii prístroja a na vhodnej kombinácii zdroj rentgenového žiarenia a detektoru. Pri rentgenovaní vzniká geometrické rozostrenie, ktoré sa dá eliminovať ale nie úplne odstrániť. Tento nežiadúci efekt je možné korigovať aj následnou softvérovou úpravou výsledného snímku. Takouto úpravou sa zaoberá táto práca. Pri softvérom zaoštrovaní existujú dva druhy metód, ktoré je možné rozdeliť na slepé metódy a na tie využívajúce konvolučné jadro.

Slepé metódy na vstupe nepotrebujú väčšinou okrem obrázku žiadne ďalšie parametre. Všetko potrebné dokážu odhadnúť. Existuje mnoho takýchto metód. Jednou z nich je aj Robust Deblurring [8].

Táto práca je zameraná najmä na metódy zaoštrujúce pomocou konvolučného jadra, keďže je známa geometria prístroja, použitá rentgenka a detektor. Slepé metódy sú použité skôr len na porovnanie výsledkov.

Konvolučné jadro určuje spôsob rozmazania snímku, čo je možné do určitej miery vrátiť, pokiaľ je známe. Možno ho získať viacerými spôsobmi a to výpočtom z geometrie prístroja, odhadom pomocou kalibračného vzorku [11], odhadom priamo z rozmazaného obrázku, ktorý je potrebné doostriť. Posledný postup využívajú slepé metódy. V tejto práci budú experimentálne porovnané rôzne metódy a ich výsledky.

Ďalším faktorom ovplyvňujúcim obraz a aj výsledky metód je šum [11, 10]. Ak nie je korigovaný, dokáže znehodnotiť obrázok. Tu taktiež existujú spôsoby ako ho dopočítať. Väčšinou sa udáva ako pomer signálu k šumu - SNR. Jeho obrátená hodnota je pomer šumu k signálu - NSR.

Digitálne snímky sa používajú a vytvárajú v širokom rozpätí zariadení. Digitálne snímače sa nachádzajú takmer vo všetkých telefónoch, kamerách, mikroskopoch, rentgenových systémoch a množstve rôznych ďalších zariadení. Môžu byť akokoľvek dokonalé, vždy sa môže v systéme vyskytnúť jav, ktorý znehodnotí snímok. Mnohokrát je tomu až nemožné zabrániť.

V programoch na úpravu fotografií sa používajú rôzne techniky. V Gimpu [13] sú najčastejšie rozostrenie masky, zaoštrovanie pomocou konvolúcie a aj pokročilejšie techniky ako Smart Sharpen. Táto technika využíva zvýraznenie hrán, ktoré následne pridá k pôvodnému obrázku. V takýchto programoch sú všeobecné metódy, ktoré nevyužívajú konvolučné jadro alebo nejaké dostupné informácie o rozmazaní. Prípadne ich odhadnú z obrázku.

Zaostrovanie sa využíva aj u mikroskopov [11]. Najdôležitejšie je správne odhadnúť a spočítať konvolučné jadro. Následne je možné použiť akúkoľvek metódu využívajúcu túto funkciu, no najčastejšie sa využíva Wienerov filter.

Pri astronomických snímkoch je populárna Lucy-Richardson metóda [14]. Tá je v tejto oblasti najpoužívanějšía kôli jej schopnosti zaostriť snímok aj pri vysokom šume.

V medicíne sa používajú rôzne filtre využívajúce konvolúciu alebo upravené dekonvolučné algoritmy, ktoré využívajú vlastnosti týchto snímok. U takýchto čiernobielych snímkoch je často dôležitý vyšší kontrast.

Tieto metódy a ich výsledky sú v tejto práci experimentálne porovnané. Na porovnanie ostroty s pôvodným obrázkom sa používa Laplaceov rozptyl [12]. Pri porovnávaní zhodnosti obrázkov sa používa SSIM [9], čo je index podobnosti, ktorý berie do úvahy ľudské vnímanie.

Experimentálne sú porovnané aj metódy na získanie konvolučného jadra. To je na porovnanie vypočítané z geometrie daného prístroja, z obrázku na základe kalibračného vzorku a na porovnanie aj odhadom pomocou slepej metódy. Výsledky sú následne vyhodnotené ako kvantitatívne, tak aj subjektívne.

Kapitola 2

Rentgen

Je zariadenie na vyšetovanie pomocou rentgenového žiarenia. Má široké využitie. V medicíne pomáha lekárom s diagnózami chorôb. V priemysle sa používa pri priemyselnej defektoskopii, kde je možné rôznymi metódami odhaliť chyby, ktoré by inak boli len ťažko detekovateľné, ak vôbec. Na letiskách a iných inštitúciách pomáha s bezpečnosťou, kde rýchlo a spoľahlivo odhalí nebezpečné predmety. Preto sa tieto systémy čoraz viac objavujú a používajú aj v iných oblastiach než v medicíne.

Táto práca je zameraná najmä na rentgeny používané v priemysle na inšpekciu kvality výrobkov, tzv. priemyselnú defektoskopiю. Tie sú špecifické tým, že sa za deň skontroluje niekoľko tisíc výrobkov rovnakého typu a nie je výnimkou, ak sú spustené niekoľko dní bez prestávky.


Takýto prístroj je tvorený okrem iných dvomi hlavnými súčasťami, a to zdrojom rentgenového žiarenia a detektorom rentgenového žiarenia, medzi ktorými býva umiestnený rentgenovaný objekt.

2.1 Zdroj rentgenového žiarenia

Rentgenové žiarenie vzniká v zdroji rentgenového žiarenia. Toto žiarenie tvorí jednu časť magnetického žiarenia [4]. Z fyzikálneho hľadiska má totožné vlastnosti ako viditeľné svetlo. Líši sa však vlnovou dĺžkou, ktorá je 10nm až 1pm . Toto žiarenie rôzne látky nepohlcujú rovnako. Toho sa využíva pri rentgenovaní, kde na detektor dopadá žiarenie, kde na určité miesta dopadne viac žiarenia, na iné menej. Tak vzniká obraz daného objektu.

Rentgenka je dióda a patrí medzi jednoduché urýchľovače častíc. Obsahuje katódu a anódu. Existuje viacero druhov zdrojov rentgenového žiarenia, pričom každý z nich je vhodnejšie použiť v inej oblasti. Podľa typu sa odvíja aj ostrosť a množstvo zachytených detailov. V priemysle sa najčastejšie používajú rentgentky s mikro ohniskom. Konštrukčne sú riešené tak aby mali malé ohnisko, ktoré má od stoviek nm , do desiatok μm . S týmto typom je možné dosiahnuť vysokého rozlíšenia. Často používaný typ, je rentgenka so statickou anódou. Tu ale môže dochádzať k prehrievaniu, čo sa dá čiastočne vyriešiť zväčšením plochy na anóde. Tým pádom sa zväčší veľkosť ohniska a následne aj rozmazanie. V porovnaní s mikroohniskovým zdrojom rentgenového žiarenia nedosahuje také výsledky.

Ďalšie typy rentgeniek sú s rotačnou anódou a typ straton. Tieto sú hlavne využívané v iných oblastiach ako v zdravotníctve, zubárstve a ďalších.



Obr. 2.1: Pozícia každého ohniska voči anóde.

2.1.1 Ohnisko rentgenky

U zdroju rentgenového žiarenia sa rozlišujú tri typy ohnísk [3, 2]. Každé z nich má vplyv na ostatné ohniská a tým pádom aj nepriamo ovplyvňujú geometrické rozmazanie. Zobrazené sú na obrázku 2.1.

Elektronové ohnisko je dané priemetom plochy dopadajúceho elektrónového zväzku, ktoré sa dá fokusovať. Fokusuje sa pomocou štrbiny v kovovom krytu vlákna katódy, tzv. Wehnelova elektróda. Výpočet elektrónového ohniska je náročný. Vypočítava sa pri vývoji rentgeniek.

Optické ohnisko je dané priemetom elektrónového ohniska v smere vyžarovaného zväzku. Odpovedá rezu zväzkom výstupného žiarenia. Jeho rozmer ovplyvňuje rozlíšenie aj rozmazanie snímok. Priamo ovplyvňuje geometrické rozmazanie. V podstate čím menšie ohnisko, tým menšia je neostrosť. Pri zmenšovaní ohniska nastáva problém s prehrievaním na anóde. Preto sa hľadajú rôzne spôsoby ako tieto problémy vyriešiť.

Zdroje rentgenového žiarenia možno rozdeliť podľa veľkosťami ich ohnísk. Všeobecne sa rozdeľujú na [2]:

- konvenčné - väčšie než 0,5mm
- minifokus - 50 mikronov až 500 micronov (0,050 mm až 0,5 mm)
- microfokus - menšie než 50 micronov

Termické ohnisko je dané plochou na anóde, na ktorú dopadajú elektróny. Je dôležité z teplotných charakteristík rentgenky. Aby sa zabránilo prehrievaniu, hľadajú sa rôzne riešenia. Jedným možným riešením je použiť rentgenku s rotačnou anódou. Ďalším je zväčšiť ho, tým pádom sa ale zväčší aj optické ohnisko, čo je nežiadúce.

2.2 Detektor rentgenového žiarenia

Spôsob vytvorenia RTG snímku sa za niekoľko rokov zmenil. Najprv sa používali fotografické dosky. Neboli až tak citlivé a boli potrebné vyššie dávky žiarenia, Toto bolo nevýhodné najmä pri rentgenovaní pacientov v lekárstve. Vysoké dávky žiarenia sú škodlivé na ľudský organizmus. Navyše uchovanie snímok tiež nebolo praktické.

Po vynálezu polovodičových senzorov sa zmenil aj spôsob získavania snímok pri rentgenoch. Grafickú dosku nahradili CCD senzory, čo prinieslo mnoho výhod. Digitálne snímky majú lepšiu kvalitu, umožňujú rôzne úpravy po zosnímaní, jednoduchšie uchovávanie a vyhľadávanie.

Existuje mnoho druhov detektorov, ktoré sa líšia použitou technológiou snímačov ako aj spôsobom zachytenia a detekovania rentgenového žiarenia. Dôležitým parametrom, ktorý je nutné brať do úvahy, je množstvo šumu pridaného do snímku snímačom. Výberom vhodného detektoru je možné výrazne zlepšiť kvalitu snímok a tým aj výsledky zaostrovacích metód.

2.3 Rozlíšenie rentgenu

Pojem rozlíšenie znamená množstvo rozoznateľných detailov na snímku. Opakom je neostrosť, kedy dochádza k rozmazaniu a tým pádom aj strate detailov. Hlavnými parametrami, ktoré ovplyvňujú toto rozlíšenie sú veľkosť ohniska zdroja rentgenového žiarenia, rozloženie scény a veľkosť detekčných jednotiek senzoru.

Z rozloženia scény je sú dôležitá vzdialenosť medzi zdrojom rentgenového žiarenia a objektom. Táto by mala byť čo možno najväčšia. Ak je rentgenovaný objekt blízko rentgenky, dochádza k vysokému rozmazaniu, čo vidno z obrázku 2.2. Naopak, vzdialenosť medzi rentgenovaným objektom a detektorom žiarenia by mala byť čo najmenšia. Tým pádom nedochádza k tak výraznému rozostreniu.

Veľkosť ohniska rentgenky by malo byť čo najmenšie. Veľkosť plochy ohniska priamo ovplyvňuje veľkosť rozmazania. V priemyselnej defektoskopii je základným parametrom pre dosiahnutie maximálneho rozlíšenia a aj následnej neostrosti snímok.

Ďalším faktorom, ktorý ovplyvní výslednú kvalitu snímku je veľkosť detekčných jednotiek na detektore rentgenového žiarenia.


Z parametrov rozloženia scény a ďalších informácií o rentgenke je možné dopočítat geometrickú neostrosť a aj zväčšenie.

2.4 Geometrická neostrosť

Geometrická neostrosť zapríčiní zväčšenie a rozostrenie objektu [1, 3]. Tomuto javu sa nedá úplne vyhnúť no možno ho čiastočne eliminovať. Ako už bolo spomenuté, je závislé na kombinácii rentgenka - detektor a aj od vzdialeností a geometrie prístroja. Vzniká v dôsledku viacerých faktorov.

Prvým je, že rentgenové žiarenie nepochádza z konkrétneho bodu ale z určitej plochy. Ak by žiarenie vychádzalo z konkrétneho bodu, nedochádzalo by k takmer žiadnemu rozmazaniu. Toto znázorňuje obrázok 2.2. Veľkosť rozmazania sa dá korigovať čiastočne vhodným výberom rentgenky, ktoré s menším ohniskom spôsobujú menšie rozostrenie.

Ďalším faktorom je rozloženie scény a jednotlivých vzdialeností medzi objektami. Toto rozloženie spôsobuje zväčšenie a aj výsledné rozmazanie.



Obr. 2.2: Geometrické rozmazanie. Vľavo, kde je zdrojom žiarenia jediný bod nedochádza k rozmazaniu. V pravo, kde je zdrojom plocha, dochádza k rozmazaniu veľkosti n .

$$n = f * \frac{y}{x} \quad (2.1)$$

Geometrická neostrosť znázornená na obrázku 2.2 a vypočíta podľa vzorca 2.1. V tejto rovnici sú jednotlivé premenné:

- x je vzdialenosť medzi zdrojom žiarenia a objektom,
- y je vzdialenosť medzi objektom a detektorom,
- f je plocha optického ohniska rentgenky,
- n udáva rozmazanie

Zo tohoto vzorca vyplýva, že je možné dosiahnuť zlepšenia rozlíšenia a zníženia rozmazania tromi spôsobmi, a to zmenšením ohniska, zmenšením vzdialenosti objekt - snímač, zväčšením vzdialenosti ohnisko-objekt.

Nie vždy sa dajú upraviť vzdialenosti v scéne na dosiahnutie ostrejšieho snímku. Problémom sú aj objemnejšie objekty, kedy časť, ktorá je bližšia k detektoru je menej rozmazaná ako vzdialenejšia časť.

Kapitola 3

Zaostrenie snímkov

Vznik snímku je v podstate premietnutie 3D scény do 2D scény. Pri tomto procese pôsobia rôzne fyzikálne javy, ktoré výsledný obraz do určitej miery skresľujú. To spôsobí okrem iných rozmazanie, zväčšenie a pridanie šumu do snímok, čo je nežiadúce. Keďže rentgenové žiarenie a viditeľné svetlo majú totožné fyzikálne vlastnosti až na vlnovú dĺžku, možno očakávať, že zaostrovacie metódy na klasické fotografie budú mať dobré výsledky aj na tých rentgenových.

3.1 Matematický popis rozostrenia snímku

Zachytenie reálneho objektu na rozmazaný snímok možno popísať matematickou operáciou konvolúcia [11]. Ukážka 2D konvolúcie je na obrázku 3.1. Opačný proces je dekonvolúcia, ktorý je možné použiť na odstránenie rozmazania. Transformáciu aplikovanú konvolúciou na ostrý snímok možno popísať Konvolučným jadrom. Táto funkcia reprezentuje spôsob skreslenia snímku systémom. Dá sa spočítať na základe vlastností rentgenu alebo meraním pomocou kalibračných snímok. Existujú rôzne základné konvolučné jadrá, ktoré zaostrujú, rozmazávajú, zvýrazňujú hrany ... Tieto funkcie ale nie sú vhodné na zaostrenie týchto snímok, pretože neodpovedajú zmenám, ktoré ovplyvnili výsledný snímok.

Ďalším faktorom, ktorý znehodnotí kvalitu snímku je šum. Nepochádza zo snímaného objektu ale bol pridaný procesom snímania. Množstvo šumu je závislé na mnohých faktoroch, no najmä na kvalite snímača a spôsobe akým zachytáva a prevádza jednotlivé hodnoty na pixely.

0	0	0	0	0	0
0	0	0	0	1	0
0	0	0	0	0	0
0	0	0	0	0	0
2	1	0	0	0	0
1	1	0	0	0	0

 \cdot

0	1	0
1	2	1
0	1	0

 $=$

0	0	0	0	1	0
0	0	0	1	2	1
0	0	0	0	1	0
2	1	0	0	0	0
8	5	1	0	0	0
7	5	1	0	0	0

Obr. 3.1: Ukážka 2D konvolúcie

Rovninca 3.1 vyjadruje matematický zápis 2D konvolúcie. Tu sa nachádza reálny ostrý obraz o , psf reprezentuje konvolučné jadro, čo je funkcia, ktorá udáva ako sa obraz znehodnotil a i je rozmazaný obraz.

$$i(x, y) = o(x, y) \oplus psf(x, y) \quad (3.1)$$

Po použití Fourierovej transformácie ($F\{\}$) na rovnicu 3.1 vznikne rovnica 3.2 v ktorej sú jednotlivé operandy prevedené do frekvenčnej oblasti.

$$I(x, y) = O(x, y) * PSF(x, y) \quad (3.2)$$

V rovnici 3.2 je operácia \oplus nahradená $*$. Klasické násobenie je výhodné, pretože vyžaduje menej operácií, čo urýchli výpočet najmä pri veľkých snímkoch.

V reálnych systémoch sa ešte vyskytuje šum, ktorý je príčinou fyzikálnych vlastností ovplyvňujúcich proces vytvorenia snímku. Tento stav vyjadruje rovnica 3.3, kde n vyjadruje pridaný šum.

$$i(x, y) = (o \oplus psf)(x, y) + n(x, y) \quad (3.3)$$

Konvolúcia má široké využitie. Vychádza z nej definícia pre dekonvolúciu, ktorá sa využíva v mnohých zaostrovacích metódach. Využíva sa aj pri rozmazaní a vyhladení obrázku, zvýraznení hrán a iných operáciách.

Kapitola 4

Konvolučné jadro (PSF)

Aby deconvolúcia fungovala čo najspoľahlivejšie, je potrebné konvolučné jadro [11, 10] čo je funkcia, ktorá určuje ako systém skresľuje snímky. Následne pomocou nej je možné opraviť neostrosť a rozmazanie. Výpočet tejto funkcie je možné vykonať z kalibračného obrázku alebo priamo z geometrie prístroja ak sú známe parametry rentgenky a jednotlivé vzdialenosti medzi rentgenkou a detektorom.

Konvolučné jadro pre rentgeny je špecifické aj tým, že v každej vzdialenosti medzi rentgenkou a detektorom má inú veľkosť. To znamená, že pre každú vrstvu ho treba vypočítať zvlášť.

Keďže geometrické rozmazanie je závislé na tvare ohniska rentgenky, konvolučné jadro bude mať tiež rovnaký tvar. Ak má tvar kruhu, stačí hodnotu vypočítať len raz v jednom smere. Rozmazanie bude v každom smere rovnaké. Ak má ale oválny tvar, bude treba rozmazanie vypočítať pre každú osu x aj y . Môže sa stať, že ohnisko má nejaký netypický tvar. V tomto prípade sa vypočítava v každom smere zvlášť. Konvolučné jadro pri rentgenových systémoch konštantná lineárna funkcia. Obvykle pri klasických fotoaparátach, mikroskopoch a iných optických prístrojoch ho tvorí Gaussova funkcia. Ďalším špecifikom, ktorý musí konvolučné jadro spĺňať je že musí byť normalizované [10]. Túto podmienku vyjadruje rovnica 4.1, kde w je šírka konvolučného jadra, h je výška konvolučného jadra, o je samotná dvojrozmerná funkcia. Pri tomto výpočte nezáleží na okolí konvolučného jadra, pri výpočte sa neberie do úvahy. To je pri každom jadre teoreticky nekonečné s hodnotou 0. Pri každej metóde ho tvorí určitý výrez, minimálne s veľkosťou jadra. Dôležité je aj určenie stredu v takomto jadre. Na obrázku 4.1 sú ukážky jednoduchých konvolučných jadier.

$$\sum_{x=0}^w \sum_{y=0}^h o(x, y) = 1 \quad (4.1)$$

Normalizácia môže mať dve podoby:

- normalizuje sa samotné konvolučné jadro, kde suma hodnôt je rovná jednej
- normalizuje sa výsledná hodnota po konvolúcii.

Normalizácia je dôležitá kôli zachovaniu kontrastu a dynamického rozsahu. Ak by sa tento postup neaplikoval, hodnoty by boli mimo pôvodný rozsah, čo by spôsobilo ich orezanie.

0	0	0
0	1	0
0	0	0

0	0	0
0	0	1
0	0	0

Obr. 4.1: Ukážka 2D konvolučného jadra. Vľavo je konvolučné jadro identity, takže po aplikovaní vznikne identický obrázok. Vpravo je konvolučné jadro, po ktorého aplikovaní vznikne posunutý obraz o jeden pixel.

4.1 Výpočet konvolučného jadra z geometrie prístroja

Tento typ výpočtu som odvodil zo vzorca 2.1 na získanie veľkosti rozmazania. Je tu ale potrebné poznať všetky parametre prístroja aj pozíciu rentgenovaného objektu. Konkrétne je potrebné vedieť veľkosť optického ohniska rentgenky, vzdialenosť rentgenka - objekt, vzdialenosť objekt - detektor, rozmery detekčnej plochy a rozlíšenie detektoru v pixeloch. Vzdialenosť medzi zdrojom rentgenového žiarenia a objektom sa meria od optického ohniska, preto je dôležité v prístroji poznať jeho polohu, prípadne ju zistiť z dokumentácie.

$$np = \frac{n * wp}{w} \quad (4.2)$$

Najprv je potrebné vypočítať rozmazanie podľa vzorca 2.1. Toto číslo vyjadruje rozmazanie v jednotkách, v ktorých sú namerané všetky vzdialenosti, čo je väčšinou v milimetroch. Preto je túto hodnotu potrebné previesť na pixely aby veľkosť odpovedala rozmazaniu na snímku v pixeloch. Tento prevod vyjadruje rovnica 4.2, kde:

- n - veľkosť rozmazania
- w - šírka detekčnej plochy
- wp - počet pixelov detekčnej plochy na šírku
- np - počet pixelov konvolučného jadra odpovedajúcich rozmazaniu v danom smere

Výsledná hodnota odpovedá rozmazaniu na snímku v pixeloch. Pomocou tejto hodnoty možno vytvoriť konvolučné jadro.


4.2 Odhad konvolučného jadra z kalibračného vzorku

V tejto časti budem prezentovať postupy, ktoré som navrhol na automatickú detekciu rozmazania zo snímku.

Pri týchto výočtoch sa vykoná odhad na základe zrentgenovaného kalibračného vzorku. Ten by mal byť tenký s výraznými hranami. Môže to byť pásik, krúžok, guľička, prípadne pliešok, ktorá obsahuje diery. Dôležité je aby materiál pohltil žiarenie, pričom by sa malo z výsledného snímku jednoducho detekovať a odhadnúť rozmazanie. Z guľičky alebo krúžku je možné zmerať rozmazanie v akomkoľvek smere.

Najprv sa zrentgenuje kalibračná vzorka. Následne sa v snímku detekuje hrana, čo je možné nastaviť na konkrétnu kalibračnú vzorku. Ďalej je potrebné kolmo na túto hranu

zmerať veľkosť rozmazania. To sa môže vykonať viacerými spôsobmi, pričom každý postup dáva výsledok s inou presnosťou. Navyše môže byť výrazne ovplyvnený šumom.



Obr. 4.2: Na obrázku je žltou vyznačená hrana a červenou na ňu kolmica, ktorou sa bude merať rozmazanie. Graf znázorňuje prechod na tejto hrane. Modrou su skutočné hodnoty, červenou by mali byť ideálne hodnoty.

Na obrázku 4.2 sú naznačené výsledky vykreslenia daného prechodu na hranu do grafu. Ako prvá sa detekuje hrana, čo je vyznačené žltou farbou. Následne kolmo na túto hranu možno z obrázku zistiť veľkosť prechodu, čo je vlastne veľkosť rozmazania. Keďže sa v obraze vyskytuje šum, nemožno priamo vyčítať presnú hodnotu. Priemerom viacerých kolmíc možno získať presnejšie hodnoty. Tento postup vykreslenia do grafu je vhodný pri experimentálnom zisťovaní rozmazania s rôznymi kalibračnými vzorkami. Pri reálnom nastavovaní a kalibrovaní rentgenu je potrebné tento postup plne automatizovať.

Na automatické zistenie rozmazania z obrazu som navrhol dva postupy. Prvý spočíta počet pixelov v rozsahu medzi svetlou a tmavou časťou. Algoritmus je nasledovný:

1. zistiť si maximálnu hodnotu v tmavej a minimálnu zo svetlej oblasti,
2. spočítať množstvo pixelov z prechodu, ktorých hodnoty sú v rozmedzí hodnôt z predošlého bodu

Ďalší je trochu sofistikovanejší a využíva metódu najmenších štvorcov na aproximáciu priamky v prechode rozmazania. Postup je nasledovný:

1. vypočítať priemernú hodnotu v tmavej a svetlej oblasti,
2. vziať z prechodnej oblasti hrany hodnoty, ktoré sa nachádzajú v rozmedzí hodnôt z predchádzajúceho bodu
3. týmito hodnotami preložiť priamku metódou najmenších štvorcov
4. spočítať priesečníky tejto priamky s priemernými hodnotami svetlej a tmavej oblasti,


5. vzdialenosť priesečníkov priamok na osi x určuje veľkosť rozmazania

Z veľkosti rozmazania už možno ľahko vytvoriť konvolučné jadro. Pri tejto metóde možno zvýšiť presnosť roznyými úpravami, napr. použitím inej metódy na odhad priamky prechádzajúcej bodmi, inou technikou detekovania hrany ...

Presnosť tejto metódy možno ovplyvniť aj zvolením vhodného kalibračného vzorku. Vzorka, ktorá má zaoblené okraje, nemusí byť tak presná ako tá, ktorá hranaté okraje, pretože na rentgene sa premietne čiastočne rozmazaná. Pri predošlej ukážke je nevýhodou možnosť zmerať rozmazanie len v jednom smere, maximálne v dvoch. Čo najpresnejšie konvolučné jadro možno dostať meraním vo viacerých smeroch. To možno dosiahnuť zo snímku guľôčky, prípadne pliešku z dierami,

4.3 Vytvorenie konvolučného jadra

Keďže je už známe rozmazanie, z tejto hodnoty možno vytvoriť konvolučné jadro. To má tvar optického ohniska zdroja rentgenového žiarenia. Hodnota rozmazania udáva u konvolučného jadra jeho priemer. Ohnisko môže mať aj tvar oválu, tu treba vypočítať pre osu x aj y rozmazanie zvlášť.



Obr. 4.3: Ukážka konvolučného jadra. Jeho priemer je hodnota, ktorá bola vypočítaná niektorou metódou.

Pre konvolučné jadro nie je dôležité okolie. To sa môže prispôsobiť podľa potrieb metódy, pričom pri zmene nemá žiadny vplyv na samotné jadro. Okolie je nekonečné a vo funkciách je výrez len určitej časti. Dôležité je aby pri týchto zmenách zostala veľkosť samotného jadra nezmenená.

Kapitola 5

Automatická kalibrácia zaostrovania v rentgenových prístrojoch

Pre zaostrovacie metódy je potrebné konvolučné jadro. Spôsoby ako ho získať alebo dopočítať už boli popísané. Postupy sa ale dajú určitým spôsobom automatizovať, čo by uľahčilo zaostrovanie a zrýchlilo nastavovanie a ladenie rentgenového prístroja. Možné sú viaceré varianty, pričom sú závislé od vlastností konkrétneho rentgenu. Možno ich rozdeliť do dvoch základných skupín:

- automatické dopočítavanie konvolučného jadra na základe aktuálnej polohy skenovaného objektu
- automatické dopočítanie konvolučného jadra na základe kalibračného vzorku.

Ak je v rentgenovom systéme použitý pozičný systém, v každom momente rentgenovania sú známe presné súradnice polohy objektu. Spolu s údajmi o geometrii prístroja možno tieto výpočty plne automatizovať. Pri každej zmene pozície je možné získať presné konvolučné jadro.

Ak sa pri rentgenovaní pozícia predmetu nemení a z nejakého dôvodu nie je možné použiť predošlý postup, možno použiť na výpočet jadra kalibračnú vzorku. Kalibračná vzorka je v roznych prístrojoch iná. Používa sa v tlačiarňach po výmene farieb, skeneroch, mikroskopoch a iných optických zariadeniach. V rentgenoch by to mal byť predmet, ktorý dobre pohlcuje žiarenie.

Ideálny objekt by bol malý vyplnený krúžok, prípadne guľôčka, ktoré by sa dali po drobných úpravách použiť priamo ako konvolučné jadro [11]. Toto je ale v praxi nereálne, pretože objekty by museli byť veľmi malé. Ďalšou možnosťou je platnička s dierkami. Tieto dierky by museli mať dostatočnú veľkosť, aby aj po zrentgenovaní na najvyššej možnej pozícii nedochádzalo k ich splývaniu, pretože potom by bolo nemožné presne zistiť veľkosť rozmazania. Z takéhoto vzorku by bolo možné zmerať rozmazanie v akomkoľvek smere. Na druhej strane, kalibračná vzorka by nemala byť veľmi tenká, aby bolo možné jasne rozoznať a vypočítať rozmazanie.

Tento spôsob je ideálny pri hromadných rentgenovaniach jedného typu objektu, kde sa jeho pozícia nemení. Tento spôsob ale nemusí byť tak presný ako priamy výpočet na základe údajov o rentgenovom prístroji.

Kapitola 6

Zaostrovacie metódy

Existuje nespočetné množstvo metód na zaostrovanie digitálnych snímok. Každá z nich sa snaží dosiahnuť rovnaký výsledok iným spôsobom. Metódy porovnávané v tejto práci sú založené na dekonvolúcii. Dajú sa rozdeliť na slepé metódy a metódy využívajúce konvolučné jadro.

Slepé metódy postupnou iteráciou zlepšujú odhad počiatočného konvolučného jadra, pričom majú k dispozícii len obrázky, ktorý je potrebné zaostriť, prípadne sériu zhodných obrázkov. Tento spôsob nie je vždy ideálny, keďže odhad môže divergovať a tým pádom aj výsledné zaostrenie môže byť minimálne, prípadne sa môžu v obraze vyskytnúť rôzne artefakty, ktoré ho znehodnotia.

Ďalšou možnosťou je použiť filter dekon. Existuje množstvo množstvo jadier, ktoré zaostrujú, zvýrazňujú hrany, rozmazávajú a pridávajú rôzne iné efekty [10]. Konvolúcia s takýmito funkciami ale vôbec neberie do úvahy spôsob rozmazania a nemusí mať vždy ideálne výsledky. Preto sa najviac využíva dekonvolúcia, čo je opačný proces.

Metódy využívajúce dekonvolúciu sú najpresnejšie, keďže je k dispozícii viac informácií a konvolučné jadro presne popisuje spôsob znehodnotenia snímku. To je možné dopočítať alebo zistiť kalibráciou, preto možno použiť metódy, ktoré zaostrujú na základe týchto poznatkov. Tieto vychádzajú z metódy pre dekonvolúciu. Príkladom takýchto metód sú Inverzná filtrácia [11], Wienerov filter [11, 10], Lucy-Richardson [14] dekonvolúcia a Stochastická dekonvolúcia [7].

6.1 Inverzný filter

Tento filter je založený na predpoklade vychádzajúceho z rovnice 3.2. Z tejto rovnice jednoduchou úpravou vznikne rovnica 6.1, kde $F\{\}$ je Fourierova transformácia, o je ideálny ostrý obrázok, i je rozmazaný obraz, psf je konvolučné jadro, ktorým bol rozmazaný obraz i .

$$F\{o(x, y)\} = \frac{F\{i(x, y)\}}{F\{psf(x, y)\}} \quad (6.1)$$

Predpokladom je, že znehodnotenie obrazu bolo zapríčinené lineárnou funkciou. Z toho vyplýva, že snímky by sa mali dať ľahko opraviť vydelením snímku s funkciou konvolučného jadra vo frekvenčnej oblasti a následne použiť inverznú Fourierovu transformáciu. To znázorňuje rovnica 6.1. V ideálnom prípade, keď sa v obraze nevyskytuje šum, je táto metóda postačujúca. V praxi je ale ťažko použiteľná. Ďalší faktor, ktorý sa v obraze vyskytuje

je šum. Konvolúciou sa zoslabujú vysoké frekvencie, tzn. rozmazávajú sa hrany objektov v obraze. Dekonvolúcia sa pokáša tieto frekvencie zosilniť. Keďže sa v obraze vyskytuje aj šum, ten je najviac zosilnený na vysokých frekvenciách. Tým vzniká obraz s artefaktmi, v najhoršom prípade môže byť úplne skreslený šumom.

6.2 Lucy-Richardson deconvolution

Táto zaostrovacia metóda bola odvodená z Bayesovho teorému Richardsonom a Lucy [14]. Je často využívaná v astrológii a medicíne. Jej výhoda je jej schopnosť rekonštrukcie snímok s vysokým šumom v dobrej kvalite.

$$f_{k+1}(x, y) = f_k(x, y)[h(-x, -y)] * g(x, y)/h(x, y) * f_k(x, y) \quad (6.2)$$

Rovnica 6.1 vyjadruje Lucy-Richardson dekonvolúciu. V tejto rovnici, $*$ značí operátor konvolúcie, f je odhad ostrého snímku, h je konvolučné jadro, g je pôvodný rozmazaný snímok.

Táto metóda začína pokusom o zaostrenie rozmazaného obrázku. Po každej iterácii sa obrázok zlepšuje, pričom redukuje MSE (Mean Square Error). Iterácia sa ukončí po určitom počte alebo ak sa MSE nemení vo viacerých iteráciách za sebou. Túto metódu je vhodné použiť ak je známe konvolučné jadro ale o šume nie je nič známe. Pri

6.3 Wienerov filter

Tento filter vychádza z inverzného filtru. Berie však do úvahy šum, pričom sa ho snaží redukovať tým, že snaží potlačiť zosílenie týchto frekvencií [11].

$$G(u, v) = \frac{H^*(u, v)}{|H(u, v)|^2 + \frac{P_u(u, v)}{P_s(u, v)}} \quad (6.3)$$

Rovnica 6.3 vyjadruje Wienerov filter. Táto rovnica zaostrenie obrázku $x(m, n)$, ktorý je prevedený do frekvenčnej oblasti Fourierovou transformáciou, pričom vznikne $X(u, v)$. V tejto rovnici je $H(u, v)$ Fourierova transformácia konvolučného jadra, $P_s(u, v)$ hodnota signálu vo frekvenčnej oblasti, $P_u(u, v)$ hodnota šumu vo frekvenčnej oblasti.

Wienerov filter nedokáže obnoviť frekvencie, ktoré boli znehodnotené šumom. Môže ich iba potlačiť a tým zabráni zosíleniu šumu v obraze. Tento typ filtru sa používa aj pri vyhladení a odstránení šumu z obrátu.

6.4 Stochastická dekonvolúcia

Stochastická dekonvolúcia [7] je vychádza z dekonvolúcie a je založená na náhodných prechodoch. Táto metóda využíva stochastické náhodné prechody, ktoré boli použité v metóde v algoritmu na rekonštrukciu tomografických snímok.

Kvalitu snímku zlepšuje v iteráciách. V každej z nich vyberie pixel z obrázku a overí, či salepší pridaním energie k tomuto pixelu. Na celkové doostrenie využíva konvolučné jadro. Využíva taktiež regularizáciu, čo potlačuje šum a artefakty.

Kapitola 7

Experimenty

V tejto časti sú jednotlivé experimenty ako so získaním a výpočtom konvolučného jadra, tak aj so zaostrovaním rentgenových snímok.

Použitá dátová sada SMT bola zrentgenovaná na prístroji Sciox SMT [5]. Tento prístroj má nasledovné parametre a vlastnosti:

- zdroj rentgenového žiarenia Spellmann XRB150
- optické ohnisko veľkosti $0,5mm$ tvaru kruhu
- detektor Shad-o-Box 1548 HS
- vzdialenosť detektor-strop zariadenia $525mm$, strop rtg-ohnisko $82mm$

Tabuľka 7.1 zobrazuje ďalšie informácie k tejto sade. V stĺpci pozícia je aktuálna pozícia objektu, ktorá odpovedá aj číslovaniu v sade snímok.

pozícia	zdroj - objekt	objekt-detektor	zdroj - detektor	zväčšenie	rozmazanie
1	607	0	607	1	0
2	557	50	607	1,0897	4,4883e-2
3	507	100	607	1,1972	9,8619e-2
4	457	150	607	1,3282	0,1641
5	407	200	607	1,4914	0,2457
6	377	230	607	1,6100	0,3050
7	347	260	607	1,7492	0,3746
8	317	290	607	1,9148	0,4574
9	287	320	607	2,1149	0,5574
10	257	350	607	2,3618	0,6809
11	227	380	607	2,6740	0,8370
12	197	410	607	3,0812	1,0406
13	167	440	607	3,6347	1,3173
14	137	470	607	4,4306	1,7153
15	107	500	607	5,6728	2,3364

Tabuľka 7.1: Prehľad jednotlivých parametrov a vzdialeností pri rôznych pozíciách. Hodnoty sú v milimetroch

Dátová sada Power bola zrentgenovaná na prístroji Sciox Power [6]. Tento prístroj má nasledovné parametre a vlastnosti:

- zdroj rentgenového žiarenia microfocus Spellmann XRB 011
- optické ohnisko veľkosti $33\mu m$ tvaru kruhu
- detektor Shad-o-Box 1548 HS
- vzdialenosť detektor-strop zariadenia $525mm$, strop rtg-ohnisko $31,75mm$

pozícia	zdroj - objekt	objekt-detektor	zdroj - detektor	zváženie	rozmazanie
1	60	496,75	556,75	9,27	0,273
2	135	421,75	556,75	4,124	0,103
3	276	280,75	556,75	2,017	0,034

Tabuľka 7.2: Prehľad jednotlivých parametrov a vzdialeností pri rôznych pozíciách. Hodnoty sú v milimetroch

7.1 Úprava snímkov pomocou konvolúcie

Konvolúciou možno do určitej miery upraviť snímok. Existuje mnoho konvolučných jadier, napr. na rozmazanie, zvýraznenie hrán, detekciu hrán a pod. Najzaujímavejšie z nich sú na doostrenie a tzv. Emboss jadro. Tieto sa snažia obrázok doostriť. Navyše Emboss pridá do snímku určité zvýraznenie, efekt tieňu.

-2	-1	0	-1	-1	-1
-1	1	1	-1	9	-1
0	1	2	-1	-1	-1

Obr. 7.1: Zaoštrovacie a Emboss konvolučné jadrá


Na ukážke 7.2 sú experimenty s konvolúciou a konvolučnými jadrami z obrázku 7.1. V prvom stĺpci sú pôvodné snímky, v druhom stĺpci sú snímky, na ktoré je aplikovaný zaoštrovací filter, v poslednom zase s Emboss filtrom.

V prvom riadku je snímok s pozíciou 0. To znamená, že má minimálne rozmazanie, pretože je blízko detektoru. Po zaoštrošení vidno určité zlepšenie. Snímok je ostrejší. Po aplikovaní Emboss filtru sa zvýraznia hrany a prechody.

V druhom riadku ale po aplikovaní zaoštrovacieho filtru je výsledok minimálny. Po aplikovaní Emboss filtru sú v snímku zvýraznené hrany ale nie sú zaoštrošené. Tento snímok má pozíciu 9.

V poslednom riadku, kde sú filtre aplikované na snímok zo Scioxu Power, sú výsledky najlepšie. To preto, že rozmazanie nie je veľké a v obraze je oveľa viac detailov ako v predchádzajúcich.

Z tohoto experimentu vyplýva, že filtrovanie obrázkov pomocou konvolúcie je vhodné na jemné doostrenie detailov, prípadne zvýraznenie hrán objektov. No nedokáže odstrániť rozmazanie.



Obr. 7.2: Zaostrenie konvolúciou a konvolučnými jadrami na doostrenie a Emboss jadrom.

7.2 Experimenty s konvolučným jadrom

Konvolučné jadro je možné získať viacerými spôsobmi. V tejto časti bude výpočítané pomocou rôznych metód a následne budú porovnané získané výsledky.

Pri týchto výpočtoch sú použité vzdialenosti geometrie prístroja Sciox SMT a pozícia 10 z dátovej sady. Jednotlivé hodnoty možno nájsť v tabuľke 7.1.

7.2.1 Výpočet na základe geometrie prístroja

Pri tomto výpočte je potrebné poznať základnú geometriu prístroja, t.j. vzdialenosti medzi hlavnými komponentmi. Tento výpočet je založený na vzorci 2.1 a jednotlivé vzdialenosti sú znázornené na obrázku 2.2. V tomto prípade majú premenné nasledovné hodnoty:

- $x = 257mm$ - vzdialenosť zdroj rentgenového žiarenia - objekt,
- $y = 350mm$ - vzdialenosť objekt - detektor,
- $f = 0,5mm$ - veľkosť ohniska zdroja rentgenového žiarenia

Po dosadení a vypočítaní

$$n = 0,5mm * \frac{350mm}{257mm} \quad (7.1)$$
$$n = 0,6809mm$$

Táto hodnota udáva rozmazanie v milimetroch. Tú je ešte potrebné previesť na pixely. Potrebné sú hodnoty rozlíšenie detektoru v pixeloch a veľkosť detekčnej plochy v milimetroch.

$$np = 0,6809mm * \frac{1548px}{102mm} \quad (7.2)$$
$$np = 10,334px$$

Z tejto hodnoty je možné vytvoriť konvolučné jadro. Keďže optické ohnisko má tvar kruhu, konvolučné jadro bude mať rovnaký s priemerom 10,334px alebo 0,6809mm. Toto odpovedá rozmazaniu snímku z dátovej sady SMT, z CU desky vrstvy 10.

7.2.2 Odhad konvolučného jadra z obrázku

Pri tomto odhade je potrebné mať zrentgenovaný objekt, z ktorého by bolo možné odhadnúť veľkosť rozmazania. Budú tu použité obe metódy popísané v časti 4.2. Tieto hodnoty sú merané na zvislej hrane z 10 vrstvy snímku CU deska.

	Metóda interpolácie	Počet pixelov v rozsahu
1	10,66px	12px
2	9,2463px	10px
3	12,1843px	13px
4	9,0858px	12px
5	7,6967px	13px


Tabuľka 7.3: Hodnoty výsledkov metód na piatich náhodných miestach zvislej hrany

V tabuľke 7.3 sú výsledky dvoch metód, ktoré boli počítané na piatich rôznych náhodných miestach. Z tabuľky vyplýva, že presnejšia je metóda interpolácie. Hodnoty sa

pohybujú v dosť veľkom rozsahu, čo je spôsobené šumom. Na získanie čo najpresnejšej hodnoty možno urobiť priemer viacerých výsledkov. Takto sa čiastočne eliminuje vplyv šumu na výsledky. Prípadne je možné upraviť samotný snímok pred odhadom. Tu treba vykonať úpravu, ktorá nebude mať vplyv na rozmazanie.

7.2.3 Porovnanie výsledkov

Pre porovnanie je použitý Robust Deblurring Software [8], čo je slepá metóda, ktorá odhadne konvolučné jadro priamo z obrázku. V tejto metóde bol použitý výrez z 10 vrstvy snímku desky.



Obr. 7.3:

Na obrázku 7.3 je ukážka jadra s priemerom vypočítaným z geometrie prístroja. Ďalší obrázok znázorňuje odhadnuté konvolučné jadro. Z tejto ukážky vyplýva, že metóda slepej dekonvolúcie nedokáže dokonale odhadnúť jadro. Samotný obrázok má najväčší vplyv na tvar jadra, pričom čím viac hrán, tým lepší odhad.

V tejto časti boli porovnané metódy získania konvolučného jadra. Najpresnejšou metódou bolo získanie veľkosti rozmazania na základe geometrie prístroja a jeho vlastností. Najmenej presným bol odhad pomocou slepej metódy. Získanie konvolučného jadra pomocou kalibračného snímku nemusí byť úplne presné, keďže sa v ňom nachádza šum. Existujú spôsoby ako ho možno redukovať. Buď sa snímok upraví pred samotným odhadom alebo je metóda prispôbená tak aby bol výsledok čo najmenej ovplyvnený šumom.

7.3 Experimenty s dekonvolučnými metódami

V tejto časti budú experimentálne porovnané výsledky Inverzného filtru, Wienerovho filtru, Lucy-Richardson dekonvolúcie a Stochastickej dekonvolúcie.

Tieto metódy potrebujú k správne zaostreniu konvolučné jadro, čo bolo experimentálne získané v predchádzajúcej časti. Jadrá pre iné pozície sa získajú rovnakým spôsobom. Ďalším parametrom, ktorý je potrebný u Wienerovho filtru je šum, ktorý bude je treba dopočítať.

7.3.1 Spôsob vyhodnotenia výsledkov metód

Vyhodnotenie metód je možné viacerými spôsobmi:

- vizuálne vyhodnotenie, ktoré je subjektívne,
- použitie metódy na zhodnotenie výsledkov, čo je objektívne hodnotenie

Prvý spôsob je najjednoduchším pozretím na obrázok, porovnaním s predchádzajúcim a následne subjektívnym vyhodnotením. Tento spôsob ale nie je vždy najvhodnejším, pretože nedokáže v každom prípade určiť lepší výsledok. Keďže na toto nie je žiaden postup ani kritériá, každý môže vyhodnotiť inak. Navyše pri malých rozdieloch je ťažké vybrať lepší snímok. Na druhej strane tento spôsob je tiež dôležitý, keďže pri rentgenových snímkoch mnohokrát vyhodnocuje kvalitu výrobku operátor obsluhujúci rentgenový prístroj. Preto je dôležité aby mali snímky z tohoto hľadiska čo najvyššiu kvalitu.

Ďalší spôsob je použitie metódy, ktorá porovná jednotlivé výsledky a kvantitatívne rozhodne určitou hodnotou na stupnici o jeho kvalite. Tieto metódy by ale mali zohľadňovať ľudské vnímanie a vyhodnocovanie obrazu. Takýto spôsob je objektívny a oveľa presnejší. Možno použiť nasledujúce metódy:

- Mean-squared error (MSE),
- Structural Similarity (SSIM) Index

Mean-squared error udáva hodnotu porovnávajúcu priemernú odchýlku medzi pôvodným a filtrovaným obrazom. Toto porovnanie je rýchle na výpočet ale nemusí odpovedať ľudskému hodnoteniu.

Structural Similarity Index vyjadruje podobnosť dvoch obrazov hodnotou v rozmedzí -1 až 1, kde 1 vyjadruje ich zhodnosť, -1 zase naopak ich nezhodnosť. Táto metóda berie do úvahy ľudské vnímanie scény a objektov. Tento index sa vypočítava vo viacerých výrezoch obrazu. Takto sa postupne porovnávajú oba obrazy.


Ostrosť snímku možno určiť viacerými metódami. Jednou z nich je transformácia obrazu do frekvenčnej oblasti a podľa distribúcie jednotlivých frekvencií určiť ostrsosť prípadne rozmazanie. Tu je ale problém so shodnosťou obrazu, keďže je možné porovnať iba frekvencie a ich zmeny.

Ďalšou metódou na určenie a porovnanie ostrosti je pomocou Laplaceovho rozptylu [12]. Pri tejto metóde sa aplikuje Laplaceov filter na daný obraz a následne sa vypočíta hodnota, ktorá vyjadruje ostrosť obrazu. Tá sa získa ako rozptyl v danom snímku. Takto je možné priamo porovnávať s pôvodným obrazom.

7.3.2 Šum

Vstupom pre Wienerov filter je rozmazaný obrázok, konvolučné jadro a pomer šumu k signálu (NSR). Prvé dva vstupné parametre sú známe. Tretí je potrebné dopočítať. Jedným zo spôsobov je odhad šumu priamo z obrázku. Pomer signálu šumu (SNR) je prevrátenou hodnotou NSR. Niktoré metódy počítajú s touto hodnotou.

Odhadnúť sa dá z oblasti obrázku, na ktorom nie je žiaden prechod alebo hrana. Ako prvé je potrebné získať pôvodný obrázok bez šumu. Tu je možné vziať buď priemernú hodnotu intenzity alebo rozmazaný zašumený obrázok. Následne je potrebné odčítať rozmazaný obrázok od zašumeného. Týmto sa získa šum z obrazu. Tento je potrebné podeliť šum s pôvodným obrázkom. Takto sa získa NSR. Toto ale reprezentuje pomer všetkých hodnôt medzi šumom a pôvodným obrázkom, preto je potrebné vziať ich priemernú hodnotu. Tento postup je znázornený na obrázkoch 7.4.



Obr. 7.4: Prvý pôvodný zašumený výrez zo snímku. Ďalší je rozmazaný gaussovým filtrom o veľkosti 10x10. Posledný je šum získaný rozdielom prvých dvoch.

7.3.3 Inverzná a Lucy-Richardson dekonvolúcia


Tieto metódy majú ako vstupné parametre rozmazaný obraz a konvolučné jadro. Z výsledkov experimentu vyplýva, že inverzný filter má iba v jednom prípade dobré výsledky. A to kde bolo rozmazanie minimálne. Inak je takmer nepoužiteľný, pretože koeficient podobnosti má dosť nízky.

Na obrázku 7.5 sú grafy znázorňujúce výsledky tohoto experimentu. Prvý graf udáva podobnosť s pôvodným snímkom. Modrou je znázornená podobnosť po Inverznej filtrácii, červenou po Lucy-Richardson dekonvolúcii

Podobnosť po zaostrení inverzným filtrom je minimálna, pretože bol zesílený šum v obraze. Jedine v tretej vrstve je podobnosť maximálna. Môže to byť spôsobené práve malým rozmazaním. Inak je táto metóda v praxi takmer nepoužiteľná kôli šumu, ktorý obraz výrazne znehodnotí.

Podobnosť po zaostrení Lucy Richardson dekonvolúciou je podobnosť pri všetkých snímkoch vysoká, pričom klesá minimálne. Na druhom grafe v 7.5 sú červenou výsledky po zaostrení, modrou je ostrosť pôvodného snímku. Táto metóda dokáže do určitej miery zaostriť snímky s menším rozmazaním, pričom postupne klesá až pri najväčšom rozmazaní ešte zhoršuje ostrosť.

V tabuľke 7.4 sú podrobné namerané hodnoty. Na 7.7 ukážka výsledkov experimentu.



Obr. 7.5: Výsledky prvého experimentu s Inverznou metódou a Lucy Richardson dekonvolúciou. Prvý graf vyjadruje index podobnosti, druhý zaostrenie.

7.3.4 Wienerov filter a Stochastická dekonvolúcia


Najlepšie výsledky v týchto pokusoch dosiahol Wienerov filter. Je rýchly a dokáže kvalitne zaostriť snímok, pričom je nutné poznať správne konvolučné jadro a hodnotu šumu v obraze.

Na grafoch 7.6 sú znázornené výsledky druhého pokusu. Na prvom je znázornený index podovnosti s pôvodným snímkom. Červeným je po zaostrení Stochastickou dekonvolúciou, modrou po Wienerovom filtrom. Na druhom grafe je znázornená ostrosť obrazu. Modrou je pôvodný snímok, červenou po Wienerovi a žltou po Stochastickej dekonvolúcii.

Ako je vidno z grafu, Wienerov filter má vysokú podobnosť pre všetky typy snímok. Zaostrenie stúpa pre snímky s malým rozmazaním, kde dosahuje najlepšie výsledky zaostrenia. Od určitého bodu však klesá pre väčšie rozmazanie až jeminimálne, takmer žiadne. Nižšiu podobnosť a žiadne zaostrenie pri snímok s veľkým rozmazaním možno vysvetliť pridaním artefaktov do snímku po konvolúcii. Z hľadiska rýchlosti výpočtu je výhodný tento filter, keďže výpočet trvá do niekoľkých sekúnd.

Stochastická dekonvolúcia síce má lepšie zaostrenie ako Wienerov filter, má ale horší index pravdepodobnosti. Dokáže lepšie zaostriť snímky s menším až stredným rozmazaním. Pri väčšom rozmazaní sa výsledky rapídne zhoršujú. To je spôsobené tým, že v obraze sa po dekonvolúcii objavujú rôzne artefakty, ktoré obraz znehodnocujú. Výrazné sú najmä čiary po okrajoch. Stochastická dekonvolúcia je pomerne náročná na výpočet. Navyše vyššie rozlíšenie snímok a 16 bitová hĺbka ju ešte viac spomalia. Pri malých konvolučných jadrách trval výpočet niekoľko minút. No pri experimente so snímom z trinástej vrstvy, kde malo konvolučné jadro priemer 21 px trval už niekoľko desiatok minút. Výpočet prebiehal čisto pomocou procesoru. Rýchlosť by sa dala skrátiť rôznymi optimalizáciami, no najviac ak by prebiehal na grafickej jednotke. Pri bežnom rentgenovaní, kde zosnímanie trvá niekoľko sekúnd je táto metóda ťažko použiteľná.

V tabuľke 7.5 sú presné namerané hodnoty, na 7.7 ukážka výsledkov experimentu.



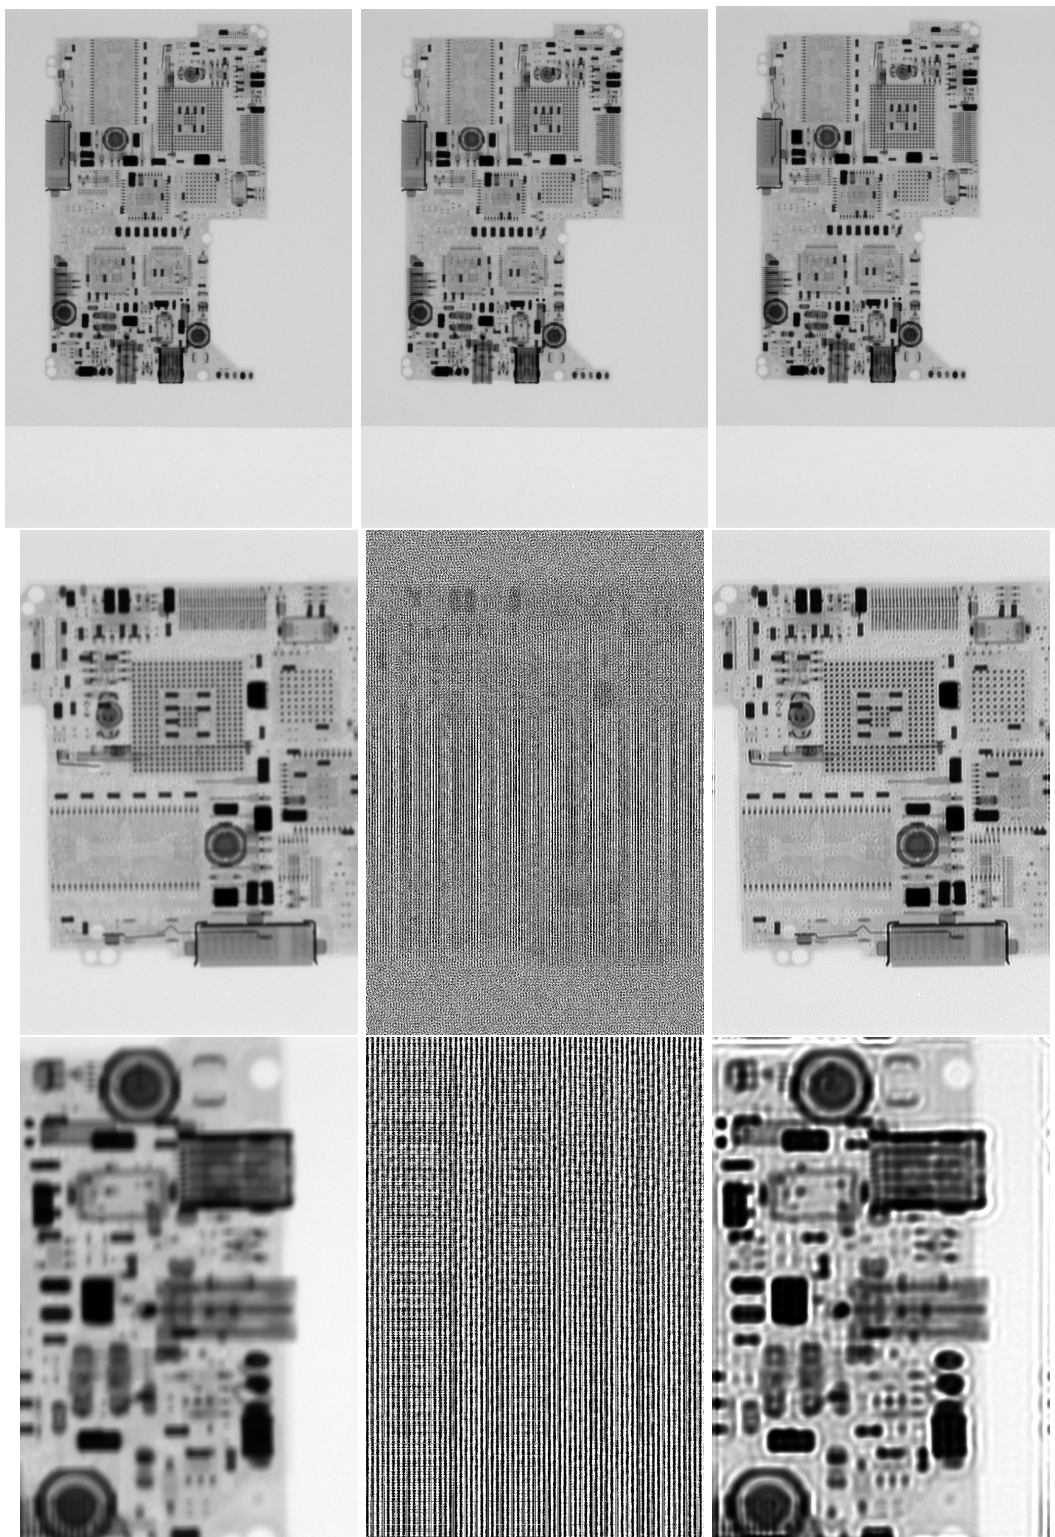
Obr. 7.6: Výsledky prvého experimentu s Inverznou metódou a Lucy Richardson dekonvolúciou. Prvý graf vyjadruje index podobnosti, druhý zaostrenie.

Pozícia	pôvodná ostrosť	Inverzný filter		Lucy-Richardson	
		podobnosť	ostrosť	podobnosť	ostrosť
3	$3,7184 \times 10^{13}$	0,9858	$5,2564 \times 10^{13}$	0,9899	$4,8124 \times 10^{13}$
4	$3,6731 \times 10^{13}$	0,0120	$3,8137 \times 10^{16}$	0,9663	$4,7402 \times 10^{13}$
5	$4,1153 \times 10^{13}$	0,0130	$3,6358 \times 10^{16}$	0,9508	$4,9050 \times 10^{13}$
6	$3,8434 \times 10^{13}$	0,0096	$4,3542 \times 10^{16}$	0,9462	$4,3582 \times 10^{13}$
7	$3,9253 \times 10^{13}$	0,0098	$4,0359 \times 10^{16}$	0,9324	$4,3910 \times 10^{13}$
8	$3,7181 \times 10^{13}$	0,0062	$4,4277 \times 10^{16}$	0,9122	$4,0983 \times 10^{13}$
9	$3,9605 \times 10^{13}$	0,0051	$2,7795 \times 10^{16}$	0,8923	$4,2822 \times 10^{13}$
10	$3,5367 \times 10^{13}$	0,0051	$3,4829 \times 10^{16}$	0,8748	$3,7752 \times 10^{13}$
11	$3,1104 \times 10^{13}$	0,0054	$3,6379 \times 10^{16}$	0,8541	$3,2186 \times 10^{13}$
12	$3,2494 \times 10^{13}$	0,0045	$3,4269 \times 10^{16}$	0,8412	$3,3876 \times 10^{13}$
13	$3,2624 \times 10^{13}$	0,0047	$2,9384 \times 10^{16}$	0,8011	$3,2327 \times 10^{13}$
14	$2,9781 \times 10^{13}$	0,0044	$3,9364 \times 10^{16}$	0,7412	$2,8866 \times 10^{13}$
15	$3,2971 \times 10^{13}$	0,0069	1,8050e+16	0,7923	3,0138e+13


Tabuľka 7.4: Prehľad výsledkov zaostrenia snímkov pomocou Inverznej a Lucy-Richardson metódy.

Pozícia	pôvodná ostrosť	Wienerov filter		Stochastická dekonvolúcia	
		podobnosť	ostrosť	podobnosť	ostrosť
3	$3,7184 \times 10^{13}$	0,9903	$4,7657 \times 10^{13}$	0,9935	$4,6162 \times 10^{13}$
4	$3,6731 \times 10^{13}$	0,9285	$6,3852 \times 10^{13}$	0,9755	$6,3132 \times 10^{13}$
5	$4,1153 \times 10^{13}$	0,8627	$7,6074 \times 10^{13}$	0,9349	$1,0288 \times 10^{14}$
6	$3,8434 \times 10^{13}$	0,8438	$6,3625 \times 10^{13}$	0,8994	$9,4068 \times 10^{13}$
7	$3,9253 \times 10^{13}$	0,8118	$6,1733 \times 10^{13}$	0,8407	$1,0979 \times 10^{14}$
8	$3,7181 \times 10^{13}$	0,7425	$5,9699 \times 10^{13}$	0,7870	$1,0574 \times 10^{14}$
9	$3,9605 \times 10^{13}$	0,7195	$5,5317 \times 10^{13}$	0,6899	$1,2144 \times 10^{14}$
10	$3,5367 \times 10^{13}$	0,7173	$4,5314 \times 10^{13}$	0,4197	$1,2144 \times 10^{14}$
11	$3,1104 \times 10^{13}$	0,7083	$3,8256 \times 10^{13}$	0,5625	$1,0888 \times 10^{14}$
12	$3,2494 \times 10^{13}$	0,6894	$3,6391 \times 10^{13}$	0,4726	$1,1863 \times 10^{14}$
13	$3,2624 \times 10^{13}$	0,6542	$3,5138 \times 10^{13}$	0,4279	$1,1331 \times 10^{14}$
14	$2,9781 \times 10^{13}$	0,6103	$3,0289 \times 10^{13}$	-	-
15	$3,2971 \times 10^{13}$	0,6770	$3,1067 \times 10^{13}$	-	-

Tabuľka 7.5: Prehľad výsledkov zaostrenia snímkov pomocou Wienerovho filtru a Stochastickej dekonvolúcie.



Obr. 7.7: Ukážka zaostrenia pomocou inverzného filtru a Lucy-Richardson dekonvolúcie na pozíciách 3, 10 a 15.



Obr. 7.8: Ukážka zaostrenia pomocou Wienerovho filtru a Stochastickej dekonvolúcie na pozíciách 3, 9 a 13.

Kapitola 8

Závěr

V tejto práci som experimentálne porovnal výsledky zaostrovacích metód. Z týchto vidno chovanie a kvalitu filtrovania pri rôznych vstupných parametroch. Najlepšou metódou je Wienerov filter, ktorý má najlepšie výsledky z týchto metód a je nenáročný na výpočet. Najhoršou metódou, ktorú v praxi ani nemožno použiť je Inverzný filter, keďže zosíli šum a tým znehodnotí obraz. Konvolúciou sa dá obrázok jemne doostriť alebo zvýrazniť hrany. Nedokáže ale zlepšiť kvalitu snímku tak ako dekonvolučné metódy.

Ďalej som porovnal a navrhol metódy na získanie a výpočet konvolučného jadra, ktoré zaostrovacie metódy používajú. Presným postupom je výpočet z geometrie prístroja. Tento by mal byť uprednostnený pred ostatnými. Ak nie sú známe údaje pre výpočet z geometrie prístroja, dá sa použiť výpočet na základe kalibračného vzorku. Tu je viacero algoritmov, no najlepšie výsledky má metóda interpolácie, ktorá sa snaží minimalizovať znehodnotenie obrazu ďalšími javmi. Presnosť sa dá zvýšiť rôznymi ďalšími úpravami.

Šum je dôležitým vstupným parametrom pre Wienerov filter, preto bol dôležitý jeho odhad. Ten som spočítal z výrezu na obrázku. Aj tu existuje viacero spôsobov, ktoré sa líšia presnosťou výsledku.

Ďalším vývojom by mohli byť experimenty s rôznymi úpravami Wienerovho filtru ako napr. Iteratívny Wienerov filter alebo pokus o zlepšenie Stochastickej metódy, najmä urýchlenie výpočtu. Iteratívny Wienerov filter by mohol mať ešte lepšie výsledky, keďže zaostruje a potlačuje šum. Prípadne by bolo vhodné použiť kombináciu viacerých metód, kedy sa jednou zaostrí obrázok, a konvolúciou zvýraznia hrany. Prípadne použiť rovnakú metódu viackrát s rôznymi parametrami.

Algoritmy a metódy sú napísané v jazykoch Python, C a Matlabu. Výsledky boli porovnané pomocou skriptu v Matlabu.

Literatúra

- [1] Center, N. E. R.: *Geometric Unsharpness*. [Online; navštívené 1.05.2018].
URL <https://www.nde-ed.org/EducationResources/CommunityCollege/Radiography/Physics/GeometricUnsharp.htm>
- [2] Center, N. E. R.: *X-ray Generators*. [Online; navštívené 1.05.2018].
URL <https://www.nde-ed.org/EducationResources/CommunityCollege/Radiography/EquipmentMaterials/xrayGenerators.htm>
- [3] Drastich, A.: *Netelevizní zobrazovací systémy*. Brno: VUT, 2001, ISBN ISBN 80-214-1974-1.
- [4] Drastich, A.: *Tomografické zobrazovací systémy*. Brno : VUT, 2004, ISBN ISBN 80-214-2788-4.
- [5] Eledus: *Kabinetový RTG přístroj pro kontrolu elektroniky SCIOX SMT*. [Online; navštívené 10.05.2018].
URL <https://www.eledus.cz/sciox-smt/>
- [6] Eledus: *Kabinetový RTG přístroj pro kontrolu výroby a kompletace SCIOX Power*. [Online; navštívené 10.05.2018].
URL <https://www.eledus.cz/sciox-power/>
- [7] Gregson, J.; Heide, F.; Hullin, M. B.; aj.: *Stochastic Deconvolution*. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2013, str. (to appear).
- [8] Li XU, J. J., Shichen Zheng: *Robust Deblurring*. [Online; navštívené 5.05.2018].
URL <http://www.cse.cuhk.edu.hk/leojia/deblurring.htm>
- [9] MathWorks, T.: *Image Quality Metrics*. [Online; navštívené 10.05.2018].
URL <https://www.mathworks.com/help/images/image-quality-metrics.html>
- [10] Milan Sonka, R. B., Vaclav Hlavac: *Image Procssing, Analysis and Machine Vision*. Thomson, 2008, ISBN ISBN 10: 0-495-24438-4.
- [11] Pawley, J. B.: *Handbook of Biological Confocal Microscopy*. Springer, 2006, ISBN ISBN 0-387-25921-X.
- [12] Pech-Pacheco, J. L.; Cristóbal, G.; Chamorro-Martínez, J.; aj.: *Diatom Autofocusing in Brightfield Microscopy: a Comparative Study*. In *ICPR*, 2000.
- [13] Team, T. G. H.: *The Gimp documentation*. [Online; navštívené 1.05.2018].
URL <https://docs.gimp.org/>

- [14] Thakur, M.; Datar, S.: *Image Restoration Based on Deconvolution by Richardson Lucy Algorithm*. ročník 14, 08 2014: s. 161–165.